

## A New Formula for Conjugate Gradient in Unconstrained Optimization

Hussein A. Wali  
ha678413@gmail.com

Khalil K. Abbo  
kh\_196538@yahoo.com

Department of Mathematics  
College of Computers Sciences and Mathematics  
University of Mosul, Mosul, Iraq

Received on: 25/08/2019

Accepted on: 23/09/2019

### ABSTRACT

The conjugate gradient method is an important part of the methods of optimization that are not constrained by local convergence characteristics. In this research, a new formula for the conjugated coefficient is derived depending on the linear structure. The new method fulfills the regression requirement. In addition, using the Wolff search line terms, the overall convergence of the new method has been demonstrated. At the end of the research were presented numerical results that show the effectiveness of the proposed method.

**Keywords:** unconstrained optimization, conjugate gradient method, sufficient descent property.

الصيغة الجديدة للتدرج المترافق في الامثلية غير المقيدة

خليل خضر عبو

حسين علي ولي

قسم الرياضيات

كلية علوم الحاسوب والرياضيات

جامعة الموصل، الموصل، العراق

تاريخ قبول البحث: ٢٣/٠٩/٢٠١٩

تاريخ استلام البحث: ٢٥/٠٨/٢٠١٩

### المخلص

طريقة التدرج المترافق جزء مهم من طرائق الأمثلية غير المقيدة بخصائص تقاربه المحلية، وان العامل الاساسي في هذه الطريقة هو العامل المترافق في اتجاهات البحث. في هذا البحث، تم اشتقاق صيغة جديدة للمعامل المترافق اعتمادا على تركيب خطي. وتتحقق الطريقة الجديدة شرط الإنحدار. بالإضافة إلى ذلك وباستخدام شروط خط بحث وولف، تم إثبات التقارب الشامل للطريقة الجديدة. وفي نهاية البحث تم تقديم النتائج العددية التي تظهر فعالية الطريقة المقترحة.

الكلمات المفتاحية: الامثلية غير المقيدة، طريقة التدرج المترافق، خاصية الانحدار الكافي.

### 1 المقدمة: (Introduction)

طريق التدرج المترافق الخطية هي طريقة تكرارية مُصممة لإيجاد قيمة صغرى شاملة عند المتجه حقيقي

$x^* \in R^n$ . إذا كان  $f : R^n \rightarrow R$  تصغير دالة الهدف التي يعبر عنها بالصيغة الآتية:

$$\text{Minimize } f(x), \quad \forall x^* \in R^n \quad (1)$$

من الصفات المهمة أن طريقة التدرج المترافق لها القابلية على توليد مجموعة متجهات لها خاصية الترافق (Conjugacy)، إذ يمكنها أن تحسب الاتجاه الجديد  $d_{k+1}$  باستخدام الاتجاه السابق  $d_k$  والتدرج الحالي  $g_k$ ، ويمكن ان تحسب النقاط  $[x_k]$  المتولدة الجديدة عن طريق المتسلسلة :

$$x_{k+1} = x_k + \alpha_k d_k, k = 1, 2, \dots \quad (2)$$

ويختار بحيث يكون تركيباً خطياً من  $(-g_k)$  (اتجاه الانحدار الشديد) و  $d_k$  (الاتجاه السابق) ولا نحتاج لمعرفة جميع الاتجاهات السابقة  $d_0, d_1, \dots, d_{n-1}$  للمجموعة المترافقة؛ إذ  $d_{k+1}$  مترافق مع جميع الاتجاهات السابقة. وهذه الصفة تجعل هذه الطريقة تتطلب مساحة خزن وحسابات قليلة. نكتب (Abbo, Laylani, and Khudhur. 2016):

$$d_{k+1} = -g_{k+1} + \beta_{k+1} d_k \quad (3)$$

إذ  $\beta_{k+1}$  تمثل كمية عددية، تحدد بحيث يكون  $d_k$  و  $d_{k+1}$  مترافقين بالنسبة للمصفوفة. نختار اتجاه البحث الأول عند النقطة الابتدائية  $d_0 = -g_0$  (اتجاه الانحدار الشديد)، (Nocedal and Wright, 2006). إن معدل التقارب لطرائق التدرج المترافق يكون خطياً ما لم يسترجع التكرار من أكثر الصيغ شهرة.

الخيارات المختلفة للمعلمة  $\beta_{k+1}$  في خوارزميات التدرج المترافق التقليدية

$$\beta_{k+1}^{HS} = \frac{g_{k+1}^T y_k}{d_k^T y_k} \quad (\text{Hestenes-Stiefel (HS) 1952})$$

$$\beta_{k+1}^{FR} = \frac{g_{k+1}^T g_k}{g_k^T g_k} \quad (\text{Fletcher-Reeves (FR) 1964})$$

$$\beta_{k+1}^{PR} = \frac{g_{k+1}^T y_k}{g_k^T g_k} \quad (\text{Polak-Ribière (PR) 1969})$$

$$\beta_{k+1}^{DY} = \frac{g_{k+1}^T g_{k+1}}{d_k^T y_k} \quad (\text{Dai-Yuan (DY) 1999})$$

$$\beta_k^{CC} = (1 - \theta_k) \frac{g_{k+1}^T y_k}{g_k^T g_k} + \theta_k \frac{g_{k+1}^T g_{k+1}}{s_k^T y_k} \quad (\text{Andrei, 2007a})$$

$$\theta_k = \frac{(y_{k+1}^T g_{k+1})(s_k^T y_k) - (y_{k+1}^T g_{k+1})(g_k^T g_k)}{(y_{k+1}^T g_{k+1})(s_k^T g_k) - (g_{k+1}^T g_{k+1})(g_k^T g_k)}$$

$$\beta_k^{ND} = (1 - \theta_k) \frac{g_{k+1}^T y_k}{g_k^T g_k} + \theta_k \frac{g_{k+1}^T g_{k+1}}{s_k^T y_k} \quad (\text{Andrei, 2007d})$$

$$\theta_k = \frac{g_{k+1}^T s_k}{g_k^T g_{k+1}}$$

$$\beta_{k+1}^{KH2} = \frac{(g_{k+1}^T y_k)^2}{g_k^T g_k (2g_{k+1}^T y_k - \|g_{k+1}\|^2)} \quad (\text{Abbo and Khudhur, 2015a})$$

$$\beta_{k+1}^{KH1} = \frac{(g_{k+1}^T y_k)^2}{d_k^T y_k (2g_{k+1}^T y_k - \|g_{k+1}\|^2)} \quad (\text{Abbo and Khudhur, 2015b})$$

الطرائق الهجينة هي الربط بين طريقتين إحداها تمتلك خواص حسابية جيدة (Good Computational Properties) والآخرى تمتلك خواص تقارب شاملة قوية (Strong Convergence Properties). وعليه فالخوارزمية الهجينة لها حافز قوي للاستفادة من السمات البارزة لخوارزمية CG الكلاسيكية (التقليدية).

(Andrei, 2011). هناك العديد من الاقتراحات من الطرائق الهجينة من اجل الوصول الى افضل طرائق التدرج المترافق التي لها خواص التقارب و كفاءة الحسابية جيدة بشكل أساسي، وكما ان الخوارزميات الهجينة لها الحافز الكبير لتجنب الفشل ولتطوير اداء الخوارزميات التدرج المترافق الكلاسيكية فنرى ان الخوارزميات CG الهجينة احسن من الخوارزميات التدرج المترافق الكلاسيكية. (Andrei, 2009a).  
اختلاف معامل الترافق طرائق التدرج المترافق المختلفة لحل مسائل الامثلية اللاخطية وغير المقيدة.

## 2 اشتقاق الصيغة الجديدة للتدرج المترافق (The Derivation of the New CG Formals)

الفكرة من هذا الاشتقاق هو تطوير طريقة Dai and Lia اعتماداً على تركيب خطي. ان العامل الاساسي

في طرائق التدرج المترافق هو العامل الترافق الاتجاهات البحث  $d_k$  اي ان :

$$d_k^T H_j d_k = 0, \forall k \neq j \quad (4)$$

نلاحظ ان المعادلة اعلاه تكون صحيحة في حالة دالة الهدف دالة تربيعية محدبة وبحث خطي تام , يمكن اعادة صيغتها كالآتي:

$$d_{k+1}^T y_k = 0 \quad (5)$$

وفي العام 1978 قد تم تعميم الشرط الترافق ( $d_{k+1}^T y_k = 0$ ) من قبل العالم Perry بالصيغة الآتية:

$$d_{k+1}^T y_k = -g_{k+1}^T s_k \quad (6)$$

قام العالمان Dai And Laio في السنة 2001 بالتعميم الشرط الترافق المقترح من قبل Perry الى الصيغة الآتية:

$$d_{k+1}^T y_k = -t g_{k+1}^T s_k, t > 0 \quad (7)$$

وعلى اساسها اقترح معامل الترافق التالية:

$$\beta_k = \frac{g_{k+1}^T (y_k - t_k s_k)}{d_k^T y_k} \quad (8)$$

الآن, اعتماداً على تركيب محدب نقترح الصيغة التالية:

$$\beta_k = \frac{g_{k+1}^T ((1-r)y_k - r s_k)}{d_k^T y_k}$$

حيث ان  $0 < r < 1$ . ولايجاد قيمة  $r$  نتبع الخطوات الآتية:

$$d_{k+1} = -g_{k+1} + \frac{g_{k+1}^T ((1-r)y_k - r s_k)}{s_k^T y_k} s_k \quad (9)$$

نضرب المعادلة اعلاه في  $(y_k^T)$

$$d_{k+1}^T y_k = -g_{k+1}^T y_k + \left( \frac{((1-r)y_k^T g_{k+1} - r s_k^T g_{k+1})}{s_k^T y_k} \right) s_k^T y_k$$

مع بعض العمليات الجبرية وتعويض عن  $d_{k+1}^T y_k$  بـ  $(-s_k^T g_{k+1})$  نحصل على التالي:

$$-g_{k+1}^T y_k + (1-r)y_k^T g_{k+1} - r s_k^T g_{k+1} = -s_k^T g_{k+1}$$

من المعادلة اعلاه نحصل على الآتي:

$$-y_k^T g_{k+1} + y_k^T g_{k+1} - r y_k^T g_{k+1} - r s_k^T g_{k+1} = -s_k^T g_{k+1} \quad (10)$$

من المعادلة (10) نحصل على قيمة

$$\Gamma = \frac{s_k^T g_{k+1}}{(y_k^T g_{k+1} + s_k^T g_{k+1})} \quad (11)$$

### خوارزمية (2.1) (KHC Algorithm)

- الخطوة 1:** اختر قيمة ابتدائية  $x_1$  ،  $\varepsilon > 0$  ، ضع  $g_1 = \nabla f_1$  ،  $d_1 = -g_1$  و  $k = 1$  .  
**الخطوة 2:** إذا كان  $\|g_k\|_\infty \leq \varepsilon$  اذن توقف ،  $x_k$  هو النقطة المثلى . وإلا اذهب إلى الخطوة 3  
**الخطوة 3:** احسب طول الخطوة  $\alpha_k > 0$  يحقق شرطي Wolfe القويين .

$$f(x_k + \alpha_k d_k) \leq f(x_k) + c_1 \alpha_k \nabla f(x_k)^T d_k$$

$$|\nabla f(x_k + \alpha_k d_k)^T d_k| \leq c_2 |\nabla f(x_k)^T d_k| ,$$

- الخطوة 4:** احسب  $x_{k+1} = x_k + \alpha_k d_k$  . واحسب  $f_{k+1}$  و  $g_{k+1}$  ، احسب  $y_k = g_{k+1} - g_k$  و  $s_k = x_{k+1} - x_k$  .  
**الخطوة 5:** احسب اتجاه البحث  $d_{k+1}$  حسب المعادلة (3) .

- الخطوة 6:** إذا كان معدل التقارب  $|g_{k+1}^T g_k| > 0.2 \|g_{k+1}\|^2$  تحقق اذن ضع  $d_{k+1} = -g_{k+1}$

$$\alpha_{k+1} = \alpha_k \left( \frac{\|d_k\|}{\|d_{k+1}\|} \right) \quad \text{الخطوة 7: احسب قيمة ابتدائية}$$

- الخطوة 8:** ضع  $k = k + 1$  و اذهب إلى الخطوة 2.

### 3 بعض الخواص النظرية للخوارزمية الجديدة

نبرهنها مثل خاصية الأنحدار من هذه الخوارزمية وخاصية الترافق .

#### النظرية (3.1)

سوف نفرض الفرضيات التالية على دالة الهدف

(i) مستوى المجموعة (Level Set)  $S = \{x \in R^n: f(x) \leq f(x_0)\}$  مقيدة عند النقطة المعطاة. اي يوجد

$$\|x\| \leq B, \forall x \in S \quad \text{بحيث ان } B > 0$$

(ii) دالة الهدف  $f$  مستمرة وقابلة للاشتقاق في بعض الجوار  $N$  لمستوى المجموعة  $S$  ، وتدرجاتها تكون مستمرة

ليبيشتر (Lipschitz Continuous) ، اي يعني يوجد ثابت  $L > 0$  بحيث ان

$$\|g(x) - g(y)\| \leq L \|x - y\|, \forall x, y \in N \quad (12)$$

باستخدام الفرضية ، نحصل على الاتي:

يوجد ثابت  $\Gamma > 0$  بحيث ان

$$\|\nabla f(x)\| \leq \Gamma, \forall x \in S \quad (13)$$

(Laylani, , Abbo, and Khudhur. 2018), (Jabbar, Abbo and Khudhur. 2018)

### 4 خاصية الأنحدار للصيغة الجديدة (The Descent Property of the new formula)

سوف نبرهن خاصية الانحدار الكافي (Sufficient Descent Property) للصيغة الجديدة المقترحة

لخوارزمية التدرج المترافق ويعبر عن خاصية الانحدار الكافي لخوارزمية التدرج المترافق بالصيغة التالية :

$$g_{k+1}^T d_{k+1} \leq -c \|g_{k+1}\|^2 \quad \text{for } k \geq 0 \text{ and } c > 0 \quad (14)$$

ومن جهة اخرى، يحقق لنا شرط (Lipschize)  $y_k \leq L s_k$  المتباينة التالية:

$$s_k^T y_k \leq L \|s_k\|^2 \quad (15)$$

(Laylani, , Abbo, and Khudhur. 2018)

#### المأخوذة (4.1)(lemma):

نفرض ان الفرضيتين (i),(ii) في النظرية (3.1) قد تحققت. لذا  $g_k$  قد اثبتنا بواسطة الشرح

$$g_k^T g_{k-1} \geq 0$$

البرهان:

لتكن  $g_i(x_k)$  يمثل العنصر ذو الموقع  $i$  من  $g_k$

$$g_k = (g_i(x_k)), i = 1, 2, \dots, n$$

اذا فرضنا ان لدينا حالتين كالاتي:

اولا: اذا كانت اما  $g_i(x_k) = 0$  او  $g_i(x_{k-1}) = 0$  اذن  $g_i(x_k)g_i(x_{k-1}) = 0$  بمعنى النتيجة صحيحة.

ثانيا: اذا كانت اما  $g_i(x_k) \neq 0$  او  $g_i(x_{k-1}) \neq 0$  اذن يوجد حالتان جزئيتان وهما:

اذا كانت  $g_i(x_k) < 0$  و  $g_i(x_{k-1}) > 0$  و  $g_k$  تحقق شرط (Liptchiz) و  $\forall \varepsilon > 0$  بحيث ان

$$|g_i(x_k) - g_i(x_{k-1})| < \varepsilon$$
 بتغيير المعادلة اعلاه الى:

$$-\varepsilon + g_i(x_{k-1}) < g_i(x_k)$$

ويؤدي الى ان  $g_i(x_{k-1}) < g_i(x_k) + \varepsilon$  لتكن  $\varepsilon \rightarrow 0$

∴ لدينا تناقض

اذا كانت  $g_i(x_k) > 0, g_i(x_{k-1}) < 0$  و  $g_k$  مستمرة (Liptchiz) و  $\forall \varepsilon > 0$  بحيث ان

$$|g_i(x_k) - g_i(x_{k-1})| < \varepsilon$$

اذن  $g_i(x_k) < g_i(x_{k-1}) + \varepsilon$  ليكن  $\varepsilon \rightarrow 0$  ايضا نحصل على تناقض. اذن انتهى البرهان

#### النظرية (4.2):

لتكن  $d_k$  اتجاه البحث  $d_k$  ( $k \geq 0$ ) تتولد حسب الصيغة (3). نفرض ان حجم الخطوة  $\alpha_k$  تحقق شرطا Wolfe

القياسي عندئذ  $d_k$  تحقق خاصية الأنحدار الكافي (5).

البرهان:

برهان بطريقة الاستقراء الرياضي:

$$1- \text{عندما } k=1 \text{ فإن } d_1^T g_1 = -\|g_1\|^2 < 0 \rightarrow d_1 = -g_1$$

2- نفرض أن العلاقة (14) صحيحة لكل  $k$ .

3- نبرهن صحة العلاقة (5) عندما  $k = k + 1$  وذلك بضرب طرفي العلاقة  $d_{k+1}$  بـ  $g_{k+1}^T$  نحصل على

$$d_{k+1}^T g_{k+1} = -g_{k+1}^T g_{k+1} + \left( \frac{(1-r)y_k^T g_{k+1} - r s_k^T g_{k+1}}{s_k^T y_k} \right) s_k^T g_{k+1}$$

وتبسيط المعادلة اعلاه نحصل على

$$d_{k+1}^T g_{k+1} = -\|g_{k+1}\|^2 + \frac{(1-r)y_k^T g_{k+1} s_k^T g_{k+1}}{s_k^T y_k} - \frac{r(s_k^T g_{k+1})^2}{s_k^T y_k}$$

نهمل الجزء السالب من المعادلة اعلاه ونفرض ان  $c = (1-r)$  فنحصل على الصيغة الاتية:

$$d_{k+1}^T g_{k+1} = -\|g_{k+1}\|^2 + c \frac{y_k^T g_{k+1} s_k^T g_{k+1}}{s_k^T y_k}$$

نستخدم الصيغة الاتية  $s_k^T y_k \geq s_k^T g_{k+1}$  في المعادلة اعلاة نحصل على التالي:

$$d_{k+1}^T g_{k+1} \leq -\|g_{k+1}\|^2 + c \frac{y_k^T g_{k+1} s_k^T y_k}{s_k^T y_k}$$

نبسط المعادلة اعلاة نحصل على التالي:

$$d_{k+1}^T g_{k+1} \leq -\|g_{k+1}\|^2 + c y_k^T g_{k+1}$$

بما ان  $y_k^T = (g_{k+1} - g_k)^T$  نعوض عن

$$d_{k+1}^T g_{k+1} \leq -\|g_{k+1}\|^2 + c(g_{k+1} - g_k)^T g_{k+1}$$

$$d_{k+1}^T g_{k+1} \leq -\|g_{k+1}\|^2 + c\|g_{k+1}\|^2 - g_k^T g_{k+1}$$

باستخدام المأخوذة (3,1) فان  $g_k^T g_{k+1} \geq 0$  ونهمل الجزء السالب من المعادلة اعلاه:

$$d_{k+1}^T g_{k+1} \leq -\|g_{k+1}\|^2 (1-c) \leq 0$$

$$\therefore d_{k+1}^T g_{k+1} < 0$$

## 5 تحليل التقارب (Convergence Analysis)

نبرهن في هذه الفقرة على أن طريقة KHC مع اتجاه البحث  $d_k$  يتقارب تقارباً مطلقاً و نبرهن ذلك نحتاج

إلى الفرضية التالية:

### المأخوذة (5.1) (Lemma)

سوف نفرض إن الفرضية (3.1) تتحقق، والمتتابة  $\{x_k\}$  تتولد من (2)، عليه إن  $d_k$  اتجاه بحث منحدر

وطول الخطوة تحقق شرطاً (Wolfe) الاعتياديين. إذ إن

$$\sum_{k=0}^{\infty} \frac{(g_k^T d_k)^2}{\|d_k\|^2} < +\infty \quad (15)$$

إذ إن المعادلة (15) تسمى شرط (Zoutendijk Condition) التي تعد على قدر من الأهمية لبرهان التقارب

الشامل لخوارزميات الأمثلية. (Zoutendijk , 1970)

### المأخوذة (5.2) (Lemma)

سوف نفرض إن الفرضية (3.1) تتحقق، والمتتابة  $\{x_k\}$  تتولد من (3)، عليه إن  $d_k$  اتجاه بحث

منحدر و  $\alpha_k$  طول الخطوة تحقق شرطاً (Wolfe) القويين

$$f(x_k + \alpha_k d_k) \leq f(x_k) + c_1 \alpha_k \nabla f(x_k)^T d_k \quad (16)$$

$$|\nabla f(x_k + \alpha_k d_k)^T d_k| \leq c_2 |\nabla f(x_k)^T d_k| ,$$

إذ إن:

$$\sum_{k>1} \frac{1}{\|d_{k+1}\|^2} = \infty \quad (17)$$

نحصل على

$$\lim_{k \rightarrow \infty} (\inf \|g_k\|) = 0 \quad (18)$$

الدالة المحدبة بانتظام، لذلك من خلال المأخوذة (5.2) نستطيع ان نثبت النظريات الآتية.

(Dai and Liao, 2001), (Khudhur. 2015)

### النظرية (5.3):

سوف نفرض أن الفرضية (3.1) والمتتابعة  $\{x_k\}$  تتولد من (2)، على إن  $d_k$  اتجاه بحث منحدر و  $\alpha_k$  طول الخطوة تحقق شرطاً (Wolfe) القويين (16)، وأن دالة الهدف  $f$  محدبة بانتظام (Uniformly Convex Function) S في مستوى المجموعة  $S$ ، حيث يوجد ثابت  $\mu > 0$ . لذلك فإن  $\lim_{k \rightarrow \infty} (\inf \|g_k\|) = 0$  تتحقق.

البرهان:

$$\begin{aligned} \|d_{k+1}\| &= \left\| -g_{k+1} + \left( \frac{(1-r)y_k^T g_{k+1} - r s_k^T g_{k+1}}{s_k^T y_k} \right) s_k \right\| \\ \|d_{k+1}\| &= \left\| -g_{k+1} + \left( \frac{y_k^T g_{k+1} - r y_k^T g_{k+1} - r s_k^T g_{k+1}}{s_k^T y_k} \right) s_k \right\| \\ \|d_{k+1}\| &\leq \|g_{k+1}\| + \frac{\|s_k\|^2 \|g_{k+1}\| + (L - rL - r)}{1} \\ &\quad \frac{1}{L \|s_k\|} \\ \|d_{k+1}\| &\leq \|g_{k+1}\| \left( 1 + 1 - r - \frac{r}{L} \right) \\ \|d_{k+1}\| &\leq \|g_{k+1}\| \left( \frac{2L - rL - r}{L} \right) \bar{y}_k \end{aligned}$$

ومن العلاقة أعلاه نحصل على:

$$\sum_{k \geq 1} \frac{1}{\|d_k\|^2} \geq \left( \frac{1}{2L - rL - r} \right)^2 \frac{1}{\bar{y}} \sum_{k \geq 1} 1 = \infty$$

وباستخدام المأخوذة (5.2) فإن  $\lim_{k \rightarrow \infty} \|g_k\| = 0$ .

## 6 النتائج العددية (Numerical Results)

سنناقش في هذه الفقرة النتائج العددية للخوارزمية المقترحة الجديدة KHC التي حصلت عليها من استخدام

الصيغة الجديدة للمعامل المترافق لمجموعة من دوال الاختبار في الأمثلية غير المقيدة مأخوذة. (Andrei, 2008) ولتقييم أداء هذه الخوارزمية المقترحة تم اختيار (75) دالة اختبار أدرجت ضمن هذه الرسالة والموضحة في الملحق.

تم اختيار الدوال للأبعاد 1000, ..., 100,  $n$ ، وبمقارنة أداء هذه الخوارزمية المقترحة الجديدة مع خوارزميات ND, CC المقياس المستخدم لإيقاف تكرارات الخوارزميات هو  $\|g_k\|^2 = 10^{-6}$ ، وقد كتب البرنامج بلغة فورتران (بالاعتماد على برنامج Andrei (version 6.6.0) (FORTRAN 77)، إن دوال الاختبار تبدأ عادة بنقطة البداية القياسية وخلصات النتائج العددية دونت في الأشكال (1) و(2) و(3) وعن طريق البرنامج (Matlab R2009b)، إن مقياس تقييم الخوارزمية تم مقارنته بالاعتماد على طريقة ل دولان و مور (Dolan and

(more) لمقارنة كفاءة الخوارزمية المقترحة مع خوارزميات ND, CC عرف  $p = 750$  كمجموعة  $n_p$  من دوال الاختبار و  $S = 4$  عدد الخوارزميات المستخدمة. لتكن  $l_{p,s}$  يمثل عدد مرات إيجاد قيمة دالة الهدف من قبل الخوارزمية  $S$  لحل مسألة  $p$ .

$$r_{p,s} = \frac{l_{p,s}}{l_p^*}$$

حيث ان  $l_p^* = \min\{l_{p,s} : s \in S\}$  من الواضح ان  $r_{p,s} \geq 1$  لكل قيم  $p, s$ . اذا فشلت الخوارزمية في حل المسائل فأن النسبة  $r_{p,s}$  تساوى الى العدد الكبير  $M$ ، خاصية الكفاءة للخوارزمية  $S$  تعرف كدالة توزيع المتراكم على نسبة الكفاءة  $r_{p,s}$

$$\rho_s(\tau) = \frac{\text{size}\{p \in P : r_{p,s} \leq \tau\}}{n_p}$$

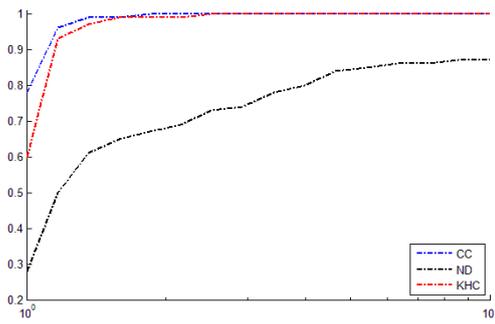
من الواضح (1)  $p_s$  يمثل النسبة المئوية لنجاح افضلية الخوارزمية  $S$ . خاصية الكفاءة يمكن أن تستخدم ايضاً في تحليل التكرارات، عدد قيم التدرج ووقت المعالج، بالإضافة للحصول على الملاحظات الواضحة في المخطط الاتي الاحداثيات الافقية ومقياس الاسي، (E. D. Dolan and J. J. Mor'e.2001)

الجدول (6.1): مقارنة الخوارزميات المختلفة للتدرج المترافق

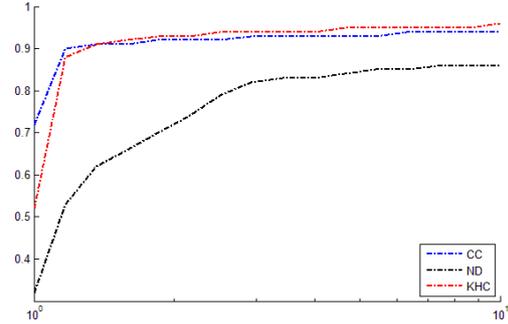
No.	Function	Dim	Algor	iter	Fg
1	Extended Trigonometric	100	Cc	19	35
			Nd	22	38
			Kh	19	35
1	Extended Trigonometric	1000	Cc	40	67
			Nd	2002	2017
			Kh	36	64
2	Extended Penalty	100	Cc	9	16
			Nd	25	49
			Kh	9	16
2	Extended Penalty	1000	Cc	12	23
			Nd	82	1870
			Kh	12	23
3	Raydan 2	100	Cc	5	10
			Nd	5	10
			Kh	5	10
3	Raydan 2	1000	Cc	5	10
			Nd	5	10
			Kh	5	10
4	Extended Himmelblau HIMMELBC (CUTE)	100	Cc	11	20
			Nd	29	58
			Kh	11	20
4	Extended Himmelblau HIMMELBC (CUTE)	1000	Cc	23	36
			Nd	31	62
			Kh	12	22
5	Extended PSC1	100	Cc	9	18
			Nd	17	34
			Kh	9	18
5	Extended PSC1	1000	Cc	8	16

			Nd	68	1945
			Kh	8	16
6	ENGVAL1 (CUTE)	100	Cc	26	48
			Nd	38	71
			Kh	28	51
6	cENGVAL1 (CUTE)	1000	Cc	93	2429
			Nd	108	2206
			Kh	95	2205
7	BDQRTIC (CUTE)	100	Cc	472	10904
			Nd	2002	2032
			Kh	340	6313
7	BDQRTIC (CUTE)	1000	Cc	2002	95072
			Nd	2002	2026
			Kh	2002	85662
8	Extended DENSCHNA (CUTE)	100	Cc	11	20
			Nd	25	38
			Kh	10	18
8	Extended DENSCHNA (CUTE)	1000	Cc	22	35
			Nd	24	38
			Kh	10	19
9	Extended DENSCHNC (CUTE)	100	Cc	14	26
			Nd	125	163
			Kh	14	26
9	Extended DENSCHNC (CUTE)	1000	Cc	14	27
			Nd	133	171
			Kh	13	24
10	Generalized Tridiagonal 1	100	Cc	23	45
			Nd	37	63
			Kh	25	43
10	Generalized Tridiagonal 1	1000	Cc	29	169
			Nd	52	463
			Kh	30	113
11	Extended Tridiagonal 1	100	Cc	11	22
			Nd	2002	2102
			Kh	12	24
11	Extended Tridiagonal 1	1000	Cc	15	28
			Nd	2002	2015
			Kh	12	24
12	Extended Himmelblau HIMMELBG (CUTE)	100	Cc	10	12
			Nd	10	12
			Kh	10	12
12	Extended Himmelblau HIMMELBG (CUTE)	1000	Cc	10	12
			Nd	10	12
			Kh	10	12
13	FLETCHCR (CUTE)	100	Cc	23	47
			Nd	39	79
			Kh	24	48
13	FLETCHCR (CUTE)	1000	Cc	30	60
			Nd	33	63
			Kh	31	56
14	Extended Block-Diagonal BD2	100	Cc	14	24
			Nd	123	157

			Kh	15	25
	Extended Block-Diagonal BD2	1000	Cc	13	24
			Nd	131	167
			Kh	15	27
15	Extended DENSCHNF(CUTE)	100	Cc	21	37
			Nd	20	34
			Kh	23	37
	Extended DENSCHNF(CUTE)	1000	Cc	24	44
			Nd	22	39
			Kh	23	38

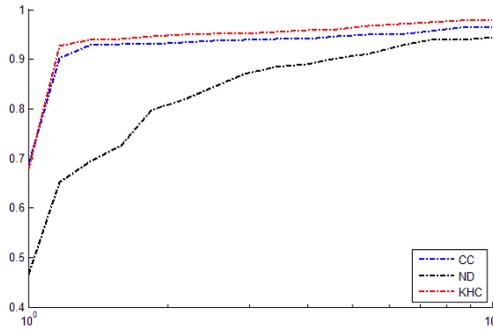


شكل (1) مقارنة بين الخوارزميات في عدد التكرارات



شكل (2) مقارنة بين الخوارزميات في عدد مرات

حساب الدالة



شكل (3) مقارنة بين الخوارزميات في الوقت

المصادر

- [1] Andrei, N., (2008), An Unconstrained Optimization Test Function collection, Advance Model. Optimization, Vol.(10), pp.147-161.
- [2] Dai, Y. H. and Liao, L. Z., (2001), "New Conjugacy Conditions and Related Nonlinear Conjugate Gradient Methods". Applied Mathematics and Optimization, Springer-Verlag, New York, USA, 43, PP.87-101.
- [3] Dolan.E. D and Mor'e.J. J, (2002), "Benchmarking optimization software with performance profiles", Math. Programming, 91, pp.201-213.
- [4] Fletcher, R., (1987), Practical Methods of Optimization. Unconstrained Optimization, A Wiley-Interscience Publication, John Wiley & Sons, Inc., New York, USA.
- [5] Zoutendijk, G. (1970) "Nonlinear programming, computational methods" in Integer and Nonlinear Programming, J. Abadie (Ed.), North-Holland: Amsterdam, pp.37-86.
- [6] Abbo, Khalil K, and Hisham M Khudhur. 2015a. "New A Hybrid Conjugate Gradient Fletcher-Reeves and Polak-Ribiere Algorithm for Unconstrained Optimization." Tikrit Journal of Pure Science 21 (1).29-124.
- [7] Abbo, Khalil K, and Hisham M Khudhur. 2015b. "New A Hybrid Hestenes-Stiefel and Dai-Yuan Conjugate Gradient Algorithms for Unconstrained Optimization." Tikrit Journal of Pure Science 21 (1).23-118.
- [8] Abbo, Khalil K, Yoksal A Laylani, and Hisham M Khudhur. 2016. "Proposed New Scaled Conjugate Gradient Algorithm for Unconstrained Optimization" 5 (7).269-276.
- [9] Abbo, Khalil K, Yoksal A Laylani, and Hisham M Khudhur. 2017. "A New Spectral Conjugate Gradient Algorithm For unconstrained Optimization."1-9.  
www.tjprc.org .
- [10] Hisham M. Khudhur. 2015. "Numerical and Analytical Study of Some Descent Algorithms to Solve Unconstrained Optimization Problems." University of Mosul College Computer Sciences and Mathematics Department of Mathematics Iraq. University of Mosul, Master Thesis.
- [11] Jabbar, Hawraz N, Khalil K Abbo, and Hisham M Khudhur. 2018. "Four--Term Conjugate Gradient (CG) Method Based on Pure Conjugacy Condition for Unconstrained Optimization." Kirkuk University Journal for Scientific Studies 13 (2).13-101.
- [12] Laylani, Yoksal A., Khalil K. Abbo, and Hisham M. Khudhur. 2018. "Training Feed Forward Neural Network with Modified Fletcher-Reeves Method." Journal Of Multidisciplinary Modeling And Optimization 1 (1).14-22.  
[http://dergipark.gov.tr/jmmo/issue/38716/392124#article\\_cite](http://dergipark.gov.tr/jmmo/issue/38716/392124#article_cite)
- [13] Nocedal, J. and Wright, S. J., (2006), Numerical Optimization Springer Series in Operation Research, 2nd edition, Springer-Verlag, New York.

- [14] Sun, W. and Yuan, Y., (2006), Optimization Theory and Methods, Nonlinear Programming, Springer Science, Business Media, LIC., New York.
- [15] Hestenes, M. R. and Stiefel, E., (1952), Methods of Conjugate Gradients for Solving Linear Systems, Journal of Research of the National Bureau of Standards, Vol. (5), No.(49), pp.409-436.
- [16] Pedregal, P., (2004), Introduction to Optimization, Springer-Verlag, Inc., New York, USA.
- [17] Powell, M. J. D., (1977), Restart Procedure for Conjugate Gradient Method, Mathematical Programming.12-241-254.
- [18] Chong, E. K. P. and Zak, S. H., (2001), An Introduction to Optimization, Jone Wiley & Sons, Inc., Canada.
- [19] Dai, Y. H. and Yuan, Y., (1999), A Nonlinear Conjugate Gradient Method with a Strong Global Convergence Property, SIAM Journal on Optimization, 10 (1).177-182.
- [20]** Fletcher, R. and Reeves, C. M., (1964), "Function Minimization by Conjugate Gradients". Computer Journal.7,142-154.